



Universidad Carlos III de Madrid.

Escuela Politécnica Superior.

**DEPARTAMENTO DE INGENIERIA ELECTRICA**

**PROYECTO FIN DE CARRERA**

**DIAGNÓSTICO DE AVERIAS DE UN CAMBIADOR DE TOMAS EN CARGA  
MEDIANTE REDES NEURONALES**

AUTOR: MIGUEL ÁNGEL PIÑAS GARCÍA

TUTOR: EDWIN RIVAS TRUJILLO

COTUTOR: ALBERTO ORDÓÑEZ

<b><i>Índice general</i></b> .....	<b><i>1</i></b>
Índice de tablas.....	3
Índice de figuras.....	5
1. Capítulo 1.....	6
INTRODUCCION.....	6
1.1. Resumen.....	6
1.2. Planteamiento del problema.....	6
1.3. Objetivos.....	7
1.4. Estructura del proyecto.....	7
2. Capítulo 2.....	8
CONSTITUCION DE UN CTC, ESTADO DEL ARTE EN REDES NEURONALES Y CASO A ESTUDIAR.....	9
2.1. Constitución de un cambiador de tomas en carga.....	8
2.1.1. Estructura de un cambiador de tomas en carga.....	8
2.1.2. Fallos de un cambiador de tomas en carga.....	9
2.2. Estado del arte en cambiadores de tomas en carga.....	10
2.2.1. Estado del arte en redes neuronales para el diagnóstico de un CTC.....	11
2.3. Caso de estudio “10” Averías.....	12
2.3.1. Indicadores de diagnóstico.....	14
3. Capítulo 3.....	16
COMPARACION DE LOS RESULTADOS DE LAS DOS REDES.....	16
3.1. Redes “10” clasificaciones.....	16
3.2. Redes “7” clasificaciones.....	18
4. Capítulo 4.....	20
REDES NEURONALES ARTIFICIALES MAPAS AUTO-ORGANIZADOS (SOM) Y REDES DE BASE RADIAL (RBF).....	20
4.1. Ventajas de las redes neuronales.....	21
4.2. Elementos constitutivos de una red neuronal artificial.....	22
4.2.1. Estados de activación.....	22
4.2.2. Función de salida o de transferencia.....	22
4.2.3. Función o regla de activación.....	23
4.3. Arquitectura de una red neuronal.....	24
4.4. Conexión entre neuronas.....	24
4.5. Estructura de los datos.....	24
4.6. Entrenamiento de una red neuronal.....	25
4.7. Tipos de redes neuronales.....	26



4.8. Redes de base radial.....	27
4.8.1. Arquitectura de una red de base radial.....	27
4.8.2. Carácter local de las redes de base radial (RBF).....	30
4.8.3. Aprendizaje de una red de base radial.....	31
4.9. Mapa auto-organizado.....	32
4.9.1. Arquitectura de una red SOM.....	32
4.9.2. Carácter local de las redes de mapas auto-organizados (SOM).....	35
4.9.3. Aprendizaje de una red SOM.....	35
5. Capítulo 5.....	37
RESULTADOS DE LAS REDES SOM Y RBF.....	37
5.1. Entradas a las redes.....	37
5.2. Estudio estadístico.....	39
5.3. Resultados de las redes.....	42
5.3.1. Resultados “10” clasificaciones.....	42
5.3.2. Resultados “7” clasificaciones.....	48
6. Capítulo 6.....	52
CONCLUSIONES Y TRABAJOS FUTUROS.....	52
6.1. Conclusiones.....	52
6.2. Trabajos futuros.....	52
BIBLIOGRAFIA.....	54

## *Índice de tablas*

Tabla 2.1.	Indicadores obtenidos del algoritmo de Rivas.....	15
Tabla 2.2.	Indicadores obtenidos del algoritmo de Rivas y los calculados para nuestras redes.....	15
Tabla 3.1.	Resultados de la red RBF para “10” clasificaciones.....	16
Tabla 3.2.	Resultados de la red RBF para “7” clasificaciones.....	18
Tabla 4.1.	Funciones de activación más utilizadas.....	22
Tabla 5.1.	Vector general de la entrada a las redes.....	37
Tabla 5.2.	Vector correspondiente a los ensayos de Buen estado.....	37
Tabla 5.3.	Vector correspondiente a los ensayos de Holgura.....	37
Tabla 5.4.	Vector correspondiente a los ensayos de contactos desgastados.....	38
Tabla 5.5.	Vector correspondiente a los ensayos de muelles sin tensión adecuada.....	38
Tabla 5.6.	Vector correspondiente a los ensayos de contactos fijos de llegada inexistente.....	38
Tabla 5.7.	Vector correspondiente a los ensayos de contactos fijos de partida inexistente.....	38
Tabla 5.8.	Vector correspondiente a los ensayos de contacto del selector desgastado.....	38
Tabla 5.9.	Vector correspondiente a los ensayos de amortiguación en el trinquete.....	38
Tabla 5.10.	Vector correspondiente a los ensayos de amortiguación en el listón.....	38
Tabla 5.11.	Vector correspondiente a los ensayos de amortiguación en listón-gatillo.....	39
Tabla 5.12.	Estudio estadístico de los indicadores DTs.....	40
Tabla 5.13.	Estudio estadístico los indicadores.....	41
Tabla 5.14.	Resultado del entrenamiento de la RBF para “10” clasificaciones.....	43
Tabla 5.15.	Resultado de la prueba de la RBF para “10” clasificaciones.....	44



Tabla 5.16	Resultados óptimos de entrenamiento y prueba de la RBF.....	44
Tabla 5.17	Resultados del entrenamiento de la RBF para “7” clasificaciones.....	48
Tabla 5.18	Resultados de la prueba de la RBF para “7” clasificaciones.....	49
Tabla 5.19	Resultados óptimos de entrenamiento y prueba de la RBF.....	50

## Índice de figuras

Figura 2.1.	Estructura básica de un cambiador de tomas en carga.....	9
Figura 2.2.	Registro de vibraciones durante un cambio de tomas con actuación del selector.....	13
Figura 2.3.	Algoritmo prestado por Rivas.....	14
Figura 3.1.	U-matriz de clasificación del SOM para “10” clasificaciones.....	17
Figura 3.2.	U-matriz de clasificación del SOM para “7” clasificaciones.....	19
Figura 4.1.	Neurona artificial.....	21
Figura 4.2.	Estructura de una red unicapa.....	23
Figura 4.3.	Estructura de una red multicapa.....	23
Figura 4.4.	Estructura de una red recurrente.....	24
Figura 4.5.	Estructura típica de una RBF.....	27
Figura 4.6.	Propagación de información en una neurona de base radial.....	28
Figura 4.7.	Activación de dos neuronas de la capa oculta en redes RBF.....	30
Figura 4.8.	Topologías presentes en un mapa auto-organizado de “7” filas por “6” columnas donde se muestra la ubicación de las neuronas.....	32
Figura 4.9.	Ejemplos de vecindades topológicos.....	33
Figura 5.1.	Evolución del entrenamiento y la prueba Vs spread para “10” clasificaciones.....	35
Figura 5.2.	U-matriz de la SOM para “10” clasificaciones.....	45
Figura 5.3.	Agrupación de defectos.....	46
Figura 5.4.	Evolución del entrenamiento y la prueba Vs spread para “7” clasificaciones.....	50
Figura 5.5.	U-matriz de la SOM para “7” clasificaciones.....	51

## Capítulo 1.

# INTRODUCCION

### 1.1. Resumen.

Un cambiador de tomas en carga por sus siglas en español CTC u OLTC por sus siglas en inglés (“On-Load Tap Changer”) es la única parte con movimiento en un transformador. Su Misión es realizar la operación de cambio de una toma a otra del devanado de regulación, modificando el número de espiras en uno de los devanados, en respuesta a un cambio de tensión en la red debido a variaciones en la carga.

De acuerdo a una encuesta internacional realizada por el CIGRE el 40% de los fallos del transformador se producen en el CTC. Es por ello que es uno de los elementos del transformador con un mayor índice de fallos. Para asegurar la fiabilidad del transformador es importante valorar el estado del mismo.

Tomando como punto de partida, el trabajo desarrollado por Rivas [1] en su tesis Doctoral, donde implementa ensayos de laboratorio para simular experimentalmente averías, basado en el análisis de la medida de la vibración.

Con base en los registros de vibraciones obtenidos Rivas implementó una metodología aplicando técnicas de pre-procesamiento y procesamiento de la señal de vibración, para hallar indicadores de diagnóstico del estado (número de impulsos de vibración, tiempo entre los impulsos de vibración, desaparición de impulsos y energía de los impulsos).

En este proyecto fin de carrera se han desarrollado dos tipos de redes neuronales: Mapa Auto-organizado (SOM) y la red neuronal de base radial (RBF), como herramientas para la evaluación automática de la condición electro-mecánica (buen estado o con algún tipo de avería) del cambiador de tomas en carga.

### 1.2. Planteamiento del problema.

Como se ha comentado anteriormente, se van a programar dos redes neuronales con el fin de que estas consigan diagnosticar el estado del cambiador de tomas en carga. Para realizar dicho diagnóstico las entradas a las redes serán indicadores que obtendremos a partir del análisis de vibración del cambiador, realizado por Rivas en su tesis [1]. Debido a que las señales de vibración del cambiador no son repetibles (cada ensayo de vibración en las mismas condiciones es diferente a los demás) se buscarán

indicadores que sean representativos de cada defecto (tales como energías y tiempos de duración de impulsos).

### **1.3. Objetivos.**

El objetivo principal del presente proyecto es optimizar dos redes neuronales e identificar que cualidades ofrecen en cuanto al diagnóstico del CTC, cuál de ellas nos ofrece mejor clasificación, mejor información y realizar una comparación de los resultados obtenidos.

Para ello se va a realizar lo siguiente:

- Se han transformado los datos originales, prestados por Rivas en formato .txt, a formato .mat.
- Obtener los indicadores de diagnóstico para la clasificación de los posibles fallos (Buen estado y “9” posibles fallos, apartado 3.3) mediante un algoritmo prestado por Rivas.
- Programar y optimizar una red SOM (Mapas autoorganizados) y una red RBF (Red de Base Radial).
- Comparar los resultados de las dos redes y estudiar su efectividad en el diagnóstico del CTC.

### **1.4. Estructura del proyecto.**

El proyecto está estructurado en “6” capítulos. En el primer capítulo se realiza una introducción sobre los problemas de un CTC y se establecen los objetivos del proyecto. En el segundo capítulo se presenta la constitución de un cambiador de tomas en carga, el estado del arte en redes neuronales y el caso a estudiar. En el tercer capítulo se realiza la comparación y el estudio de la eficacia de las redes utilizadas. En el cuarto capítulo se presenta el desarrollo de las redes neuronales utilizadas así como el funcionamiento y las partes de las redes neuronales más importantes. En el quinto capítulo se presentan los resultados obtenidos de las dos redes. Finalmente en el capítulo seis se presenta un resumen del trabajo realizado, se destacan conclusiones y posibles trabajos futuros.



## Capítulo 2.

# CONSTITUCION DE UN CTC, ESTADO DEL ARTE EN REDES NEURONALES Y CASO A ESTUDIAR.

### 2.1. Constitución de un cambiador de tomas en carga.

Un cambiador de tomas en carga o regulador, es la única parte con movimiento en un transformador. Su función es realizar la operación de cambio de una toma del arrollamiento de regulación a otra, permitiendo regular la tensión de salida del transformador a los niveles requeridos sin la interrupción de la corriente de carga. La valoración del estado electro-mecánico (buen estado o con avería) de un cambiador de tomas en carga es importante para asegurar la fiabilidad del transformador y por lo tanto del sistema de transmisión de energía eléctrica al cual se encuentre conectado

#### 2.1.1. Estructura de un cambiador de tomas en carga.

Un CTC (Figura.3.3) consta de los siguientes elementos esenciales:

- **Armario de accionamiento y mando:** contiene los elementos de mando y maniobra del CTC (motor eléctrico, etc.).
- **Mecanismo de transmisión:** está constituido por los ejes de transmisión vertical y horizontal y cajas de reenvío en ángulo.
- **Selector de tomas:** selecciona la toma en la que se desea trabajar.
- **Cabeza del regulador:** contiene los mecanismos acumuladores de energía y el accionamiento del selector.
- **Conmutador o ruptor:** Realiza la conmutación, es decir conduce la corriente de carga de la toma inicial a la toma final sin interrumpir el servicio, para ello utiliza unas resistencias o reactancias transitorias que limitan la corriente cuando éste opera.

Al dar una orden de cambio de una toma a otra, arranca el accionamiento a motor, éste mueve el mecanismo de transmisión, el cual permite que actúe o no el selector y simultáneamente que se cargue el resorte del mecanismo acumulador de energía que hace que opere el conmutador.




Figura 2.1 Estructura básica de un CTC

### 2.1.2. Fallos en un cambiador de tomas en carga.

Los fallos de un cambiador de tomas en carga pueden darse por un gran número de factores pero principalmente se deben a los siguientes:

- Diseño inadecuado
- Mala fabricación o mal control de calidad
- Operación incorrecta
- Deterioro o envejecimiento de los componentes
- Excesiva humedad en el aceite
- Mantenimiento no oportuno
- Inadecuado mantenimiento
- Montaje incorrecto de elementos después de mantenimiento
- Uso infrecuente de algunas posiciones de regulación

Los fallos en un CTC pueden ser mecánicos o eléctricos, la mayoría son mecánicos y estos producen fallos eléctricos. Los fallos más comunes en un CTC son:

- Fallo en el motor de arrastre que acciona el cambiador

- Fallo en la transmisión:
- Fallo en el mecanismo acumulador de energía.
- Asincronismo o desregulación entre el cambiador y su accionamiento.
- Depósito o acumulación de partículas quemado en los contactos del selector o conmutador.
- Desprendimiento o arranque del material del contacto.
- Fallos causados por ruptura del aislamiento.
- Fallos en las resistencias de transición o en las trencillas de conexión de las mismas.

## **2.2. Estado del arte en cambiadores de tomas en carga.**

Tradicionalmente el diagnóstico de cambiadores de tomas en carga se trataba de revisiones periódicas en función del número de maniobras. En estas revisiones se extraía el conmutador, se cambiaban las resistencias y se revisaba el selector del cambiador de tomas en carga. Esta técnica no era un método satisfactorio para el diagnóstico de fallos ya que muchos cambiadores no tenían problemas o ocurría algún fallo catastrófico en el periodo intermedio entre dos revisiones.

La medida de la señal de vibración durante el cambio de una toma a otra [7], es una técnica de tipo predictivo la cual permite realizar un diagnóstico del estado de un cambiador de tomas en carga, aun es estado incipiente.

La medida de la vibración se puede aplicar de dos maneras [1]:

- Comparando las señales de vibración obtenidas recientemente con mediciones previas o señales patrón o de referencia, lo cual permite valorar el grado de degradación del CTC.
- Comparando señales de vibración con el transformador bajo condiciones de descargo y bajo carga, lo cual permite valorar actividad de arqueo sospechosa, pero puede requerir algunas medidas previas con el transformador en descargo. Lo ideal es una combinación de ambas maneras.

### 2.2.1. Estado del arte en redes neuronales para el diagnóstico de un CTC

En este apartado se muestra como han utilizado diferentes autores redes neuronales artificiales en el diagnóstico de cambiadores de tomas en carga.

En 1998 kang et al [9], utiliza la transformada de wavelet discreta aplicada a la envolvente de la señal; los Coeficientes son posteriormente transformados mediante la transformada corta de fourrier (FFT) para obtener unos vectores de características. El error entre el vector de características de la señal de vibración patrón y cada nueva señal adquirida se denomina normalised quantisation error (NQE) y son las entradas a la red.

En el 2000 kang et al [21], aproxima la función de distribución de probabilidad del error mínimo de cuantización (MQE) a una distribución logarítmicamente normal (lognormal).

La distribución lognormal se caracteriza porque existe solo para valores positivos de la variable de estudio, es una función dependiente de dos parámetros y asocia a la media de los datos (también conocida como esperanza matemática), un valor superior a la mediana. Asimismo, la función logaritmo permite analizar con un detalle adecuado tanto la zona de pequeños valores de la variable en estudio como la zona de elevados valores de la variable bajo estudio. Gracias a estos atributos, la función de distribución lognormal de probabilidad es apropiada como modelo estadístico aplicable a la distribución del MQE.

En 2001 kang et al [22], introducen la señal de autocorrelación ( $R_{xx}$ ) de la envolvente, para diferentes valores del desfase temporal ( $\tau$ ). La función  $R_{xx}(\tau)$  es normalizada respecto de su valor máximo. Posteriormente, la función normalizada es sub-muestreada y es usada como variable de entrada a un mapa auto-organizado (SOM).

En 2002 y 2003 kang et al [16], implementan como datos de entrada a un mapa auto-organizado la envolvente alineada y normalizada y suavizada mediante wavelet de la señal de vibración de un cambiador de tomas en carga.

En 2008 simas et al [19], utiliza mapas auto-organizados como un clasificador para identificar diferentes niveles de desgaste de los contactos eléctricos del cambiador de tomas en carga. Este clasificador fue capaz de separar los patrones disponibles en cuatro distintas condiciones de funcionamiento: post-mantenimiento (sin desgaste), desgaste bajo, desgaste intermedio y desgaste severo. En su trabajo utiliza los Coeficientes de la descomposición wavelet como entradas al mapa auto-organizado.

### **2.3. Caso de estudio “10” Averías.**

En el presente proyecto fin de carrera se va a clasificar los estados de un cambiador de tomas en carga en nueve posibles fallos y el funcionamiento en buen estado.

- 1- Buen estado.
- 2- Holgura en el anclaje de las barras del selector a la estructura.
- 3- Contactos fijos del selector flojos.
- 4- Muelles de los contactos móviles sin la tensión adecuada.
- 5- Barra de anclaje del selector partida (contactos fijos de llegada inexistentes).
- 6- Barra de anclaje del selector partida (contactos fijos de partida inexistentes).
- 7- Contactos fijos de llegada del selector desgastados.
- 8- Amortiguación en el carro de accionamiento en el trinquete.
- 9- Amortiguación en el carro de accionamiento en el listón.
- 10- Amortiguación en el carro de accionamiento en el listón-gatillo.

Para conseguir esta clasificación se van a programar y optimizar dos redes neuronales (una red de base radial RBF y otra de mapas auto-organizados SOM).

La clasificación de las averías está basada en el patrón de vibraciones, por lo que los indicadores utilizados en esta han sido extraídos de las vibraciones producidas por un CTC cuando este realiza un cambio de toma.

La figura 3.9 muestra el registro de la señal de vibración en buen estado durante un cambio de tomas con actuación del selector.




Figura 2.2. Registro de vibración durante un cambio de tomas con actuación del selector.

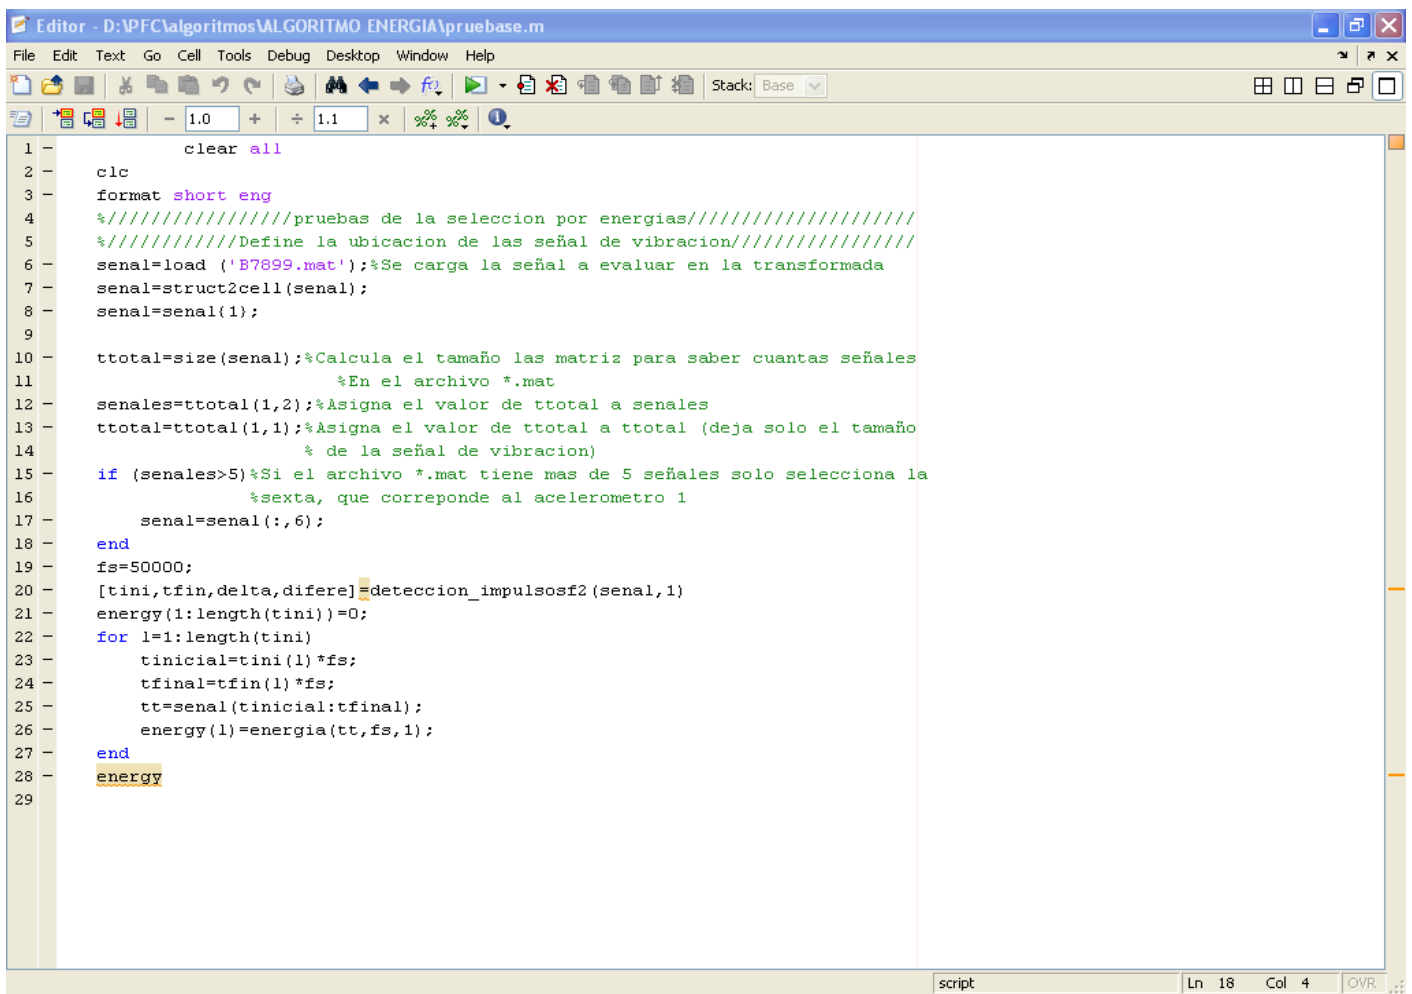
En el registro anterior se diferencian “6” impulsos.

- Impulso 1: Arranque del accionamiento motor
- Impulso 2: Actuación de las cruces de malta
- Impulso 3: Los contactos del selector finalizan su recorrido (llegan a la toma final)
- Impulso 4: Finaliza el movimiento de la cruz de malta.
- Impulso 5: Actuación del conmutador.
- Impulso 6: Parada del accionamiento a motor.

### 2.3.1. Indicadores de diagnóstico.

Los indicadores de diagnóstico utilizados han sido obtenidos mediante un algoritmo tomado de la tesis de Rivas (tutor del presente proyecto).

En la figura 2.3 se presenta el algoritmo prestado por Rivas. Para cargar el archivo .mat procedente de los acelerómetros se introduce su código en la fila “6” (en el ejemplo se carga el ensayo B789 en su novena conmutación). Los datos de los acelerómetros se encuentran en las columnas “6”, “7” y “8” de los archivos .mat para obtener los indicadores de cada uno de los acelerómetros se cambia la columna en la fila “17” (la columna “6” corresponde al primer acelerómetro, la columna “7” corresponde al segundo acelerómetro y la columna “8” corresponde con el tercer acelerómetro).



```
1 clear all
2 clc
3 format short eng
4 %//////////pruebas de la seleccion por energias//////////
5 %//////////Define la ubicacion de las señal de vibracion//////////
6 senal=load ('B7899.mat');%Se carga la señal a evaluar en la transformada
7 senal=struct2cell(senal);
8 senal=senal{1};
9
10 tttotal=size(senal);%Calcula el tamaño las matriz para saber cuantas señales
11 %En el archivo *.mat
12 senales=tttotal(1,2);%Asigna el valor de tttotal a senales
13 tttotal=tttotal(1,1);%Asigna el valor de tttotal a tttotal (deja solo el tamaño
14 % de la señal de vibracion)
15 if (senales>5)%Si el archivo *.mat tiene mas de 5 señales solo selecciona la
16 %sexta, que corresponde al acelerometro 1
17 senal=senal(:,6);
18 end
19 fs=50000;
20 [tini,tfin,delta,difere]=deteccion_impulsosf2(senal,1)
21 energy(1:length(tini))=0;
22 for l=1:length(tini)
23     tinicial=tini(l)*fs;
24     tfinal=tfin(l)*fs;
25     tt=senal(tinicial:tfinal);
26     energy(l)=energia(tt,fs,1);
27 end
28 energy
29
```

Figura 2.3. Algoritmo prestado por Rivas.

Los resultados que se obtienen del citado algoritmo se presentan en la tabla 2.1 (resultados del ensayo B 7-8-9-1).

B7891	Energía(J)	Tini(seg)	Tfin(seg)
impulso 1	1,94E-03	8,57E-01	8,97E-01
impulso 2	1,38E-04	1,45E+00	1,54E+00
impulso 3	8,82E-05	4,44E+00	4,46E+00
impulso 4	4,72E-05	4,51E+00	4,57E+00
impulso 5	6,64E-03	4,96E+00	5,11E+00
impulso 6	4,79E-04	6,19E+00	6,23E+00

Tabla 2.1. Indicadores obtenidos del algoritmo de Rivas

Se han tomado como indicadores de diagnóstico las energías correspondientes a los impulsos vistos en el apartado anterior y el tiempo que transcurre entre la aparición de los impulsos y la finalización del siguiente. Indicador que se ha llamado DT. Se ha decidido esto porque el tiempo en el que aparecen los impulsos varía con cada ensayo, mientras que el tiempo de duración entre impulsos se mantiene constante para todos los ensayos (en el apartado “5” se demuestra que los datos tomados como indicadores son homogéneos, es decir presentan valores muy parecidos).

Las energías las da el algoritmo directamente y los DTs se obtienen a partir de la siguiente expresión.

$$(3.1)$$

En la tabla 2.2 se presentan los indicadores de diagnóstico para el ensayo B-7-8-9-1, obtenidos como se ha indicado anteriormente.

B7891	Energía(J)	Tini(seg)	Tfin(seg)	Duración(seg)	DTs(seg)
impulso 1	1,94E-03	8,57E-01	8,97E-01	4,01E-02	-
impulso 2	1,38E-04	1,45E+00	1,54E+00	8,82E-02	0,6811
impulso 3	8,82E-05	4,44E+00	4,46E+00	2,40E-02	3,0087
impulso 4	4,72E-05	4,51E+00	4,57E+00	5,61E-02	0,1323
impulso 5	6,64E-03	4,96E+00	5,11E+00	1,48E-01	0,5971
impulso 6	4,79E-04	6,19E+00	6,23E+00	3,37E-02	1,2677

Tabla 2.2. Indicadores obtenidos del algoritmo de Rivas y los calculados para nuestras redes



### Capítulo 3.

## COMPARACION DE LOS RESULTADOS DE LAS DOS REDES.

El objetivo del presente proyecto fin de carrera es la comparación entre la eficiencia de los resultados de dos redes neuronales para el diagnóstico de un CTC con el fin de estudiar cual de ambas resultaría más útil a la hora de conocer el estado de dicho cambiador.

### 3.1. Redes “10” clasificaciones.

En principio el fin es intentar la clasificación de las redes en los “10” posibles fallos en los que puede encontrarse el CTC (buen estado y los “9” fallos).

Los resultados de la red de base radial para clasificar los “10” defectos (capítulo “5”) se pueden ver en la tabla 4.1:

Nº neuronas	70	70
	Entrenamiento Op =	Ensayo Op =
SPREAD	0,69	0,32
% ACIERTO B	100	100
% ACIERTO C	86,1111	100
% ACIERTO H	94,4444	91,6667
% ACIERTO T	100	100
% ACIERTO D	100	100
% ACIERTO A	100	100
% ACIERTO L	100	100
% ACIERTO G	88,8889	100
% ACIERTO P	100	100
% ACIERTO Q	88,8889	100
% ACIERTO GLOBAL	95,8333	99,1667

Tabla 3.1. Resultados de la red RBF para “10” clasificaciones

Una clasificación que en principio es muy buena, aunque la red sufre caídas en la eficiencia tanto en el entrenamiento como en la prueba para diferentes valores de spread (se realizará un estudio detallado en el capítulo 5).

La red SOM para la clasificación de los “10” defectos dio el siguiente resultado:




Figura 3.1. U-matriz de clasificación del SOM para “10” clasificaciones

Los resultados obtenidos en la RBF son mejores que los obtenidos en la SOM, clasificando los “10” defectos perfectamente con altos porcentajes de acierto, mientras que la red SOM ofrece mayor información en cuanto a la similitud entre los defectos. Gracias a esto se ha realizado una agrupación de defectos con el fin de mejorar la clasificación de las redes (se verá con todo detalle en el capítulo “5”).

### 3.2. Redes “7” clasificaciones.

Una vez agrupados los defectos se han diseñado dos redes para clasificar “7” defectos.


Los resultados obtenidos de la RBF para “7” clasificaciones se ven en la tabla 4.2:

Nº neuronas	70	70
	Entrenamiento Op =	Ensayo Op =
SPREAD	0,1	0,2209
% ACIERTO B	100	100
% ACIERTO U	100	100
% ACIERTO L	100	100
% ACIERTO D	100	100
% ACIERTO A	100	100
% ACIERTO P	94,4444	100
% ACIERTO V	100	100
% ACIERTO GLOBAL	99,2063	100

Tabla 3.2. Resultados de la RBF para “7” clasificaciones

Los resultados obtenidos, para una clasificación de “7” defectos, son excelentes. La mejora se debe a que se han agrupado perfectamente los defectos que presentaban las mismas similitudes.

En cuanto a la SOM los resultados obtenidos para la clasificación de “7” defectos ha sido la siguiente:



SOM 08-Jun-2010

Figura 3.2. U-matriz de clasificación del SOM para “7” clasificaciones

En la figura 4.2 se puede observar que hay varias neuronas ganadoras para el mismo tipo de defecto, pero se encuentran en la misma región pudiendo concluir que el análisis de esta red SOM es muy bueno teniendo “7” zonas bien diferenciadas pertenecientes a cada defecto.

El resultado de la red RBF sigue siendo mejor resultado (100 % de clasificación) que el obtenido con la SOM aunque son ambos muy buenos y la SOM sigue ofreciendo mayor información en cuanto a la similitud de los defectos.

## Capítulo 4.

# REDES NEURONALES ARTIFICIALES MAPAS AUTOORGANIZADOS Y DE BASE RADIAL.

Las redes neuronales artificiales (RNA, o en inglés ANN) son modelos matemáticos que intentan simular el funcionamiento de los sistemas nerviosos biológicos. Se trata de un sistema de interconexión de neuronas en una red que colabora para producir una salida a partir de unos datos de entrada [3]. Se suelen definir como redes de neuronas o redes neuronales. El objetivo es conseguir que las máquinas den respuestas similares a las que es capaz de dar el cerebro que se caracterizan por su generalización y su robustez.

Una definición técnica de RNA:

“Redes neuronales artificiales son redes interconectadas masivamente en paralelo de elementos simples (usualmente adaptativos) y con organización jerárquica, las cuales intentan interactuar con los objetos del mundo real del mismo modo que lo hace el sistema nervioso biológico” [2].

Las redes neuronales artificiales presentan las siguientes características:

1. El conocimiento es adquirido experimentalmente.
2. Los pesos (ganancias) de interconexión (sinapsis) varían constantemente.

### 4.1. Ventajas de las redes neuronales.

Se han utilizado redes neuronales en el presente proyecto en lugar de otros métodos porque estas presentan las siguientes ventajas:

1. No linealidad: Las redes neuronales tienen procesos de cálculos no lineales.
2. Transformación entrada-salida: El proceso consiste en dar a la red un ejemplo y modificar sus pesos en función de su salida. Aprende por lo tanto con una transformación entrada-salida.
3. Adaptabilidad: La red tiene la capacidad de adaptar sus parámetros en tiempo real.
4. Tolerancia a fallos: Debido a la interconexión masiva de neuronas, el fallo de una de ellas no altera seriamente el funcionamiento de la red.

5. Uniformidad en el análisis y diseño: Esto permite garantizar características precisas.
6. Analogía con las redes biológicas: Esto permite la utilización mutua del conocimiento de ambas áreas.

#### 4.2. Elementos constitutivos de una Red Neuronal Artificial.

En la figura 4.1 se muestra el aspecto de una neurona artificial [3]:




Figura 4.1. Neurona artificial

Los elementos que la forman son los siguientes:

- Enlaces de conexión. Parametrizados por los pesos sinápticos ( $w_{nj}$ ). Si  $w_{nj}$  es mayor que "0" entonces la conexión es excitadora pero por el contrario si  $w_{nj}$  es menor que "0" la conexión es inhibidora.
- Sumador ( $\Sigma$ ). Suma los componentes de las señales de entrada multiplicadas por  $w_{ij}$ .
- Función de activación. Transformación no lineal.
- Umbral. Desplaza la entrada.

#### 4.2.1. Estados de activación.

Los estados del sistema en un tiempo “t” se representan por un vector A(t). Los valores de activación pueden ser continuos o discretos, limitados o ilimitados. Si son discretos, suelen tomar un conjunto discreto de valores binarios, así un estado activo se indicaría con un 1 y un estado pasivo se representaría por un cero. En otros modelos se considera un conjunto de estados de activación, en cuyo valor entre [0,1], o en el intervalo [-1,1], siendo una función sigmoideal.

#### 4.2.2. Función de salida o de transferencia.

Transforma el estado actual de activación en una señal de salida. Existen cuatro funciones de transferencia típicas que determinan distintos tipos de neuronas:

- Función Escalón
- Función Lineal y Mixta
- Sigmoidal
- Función Gaussiana

#### 4.2.3. Función o regla de activación.

Se requiere una regla que combine las entradas con el estado actual de la neurona para producir un nuevo estado de activación. Esta función “F” produce un nuevo estado de activación en una neurona a partir del estado que existía y la combinación de las entradas con los pesos de las conexiones. Esa “F” es denominada función de activación, y las salidas que se obtienen en una neurona para las diferentes formas de F serán:

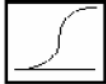

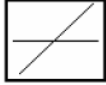



Funciones de transferencia	Fórmula	Representación Gráfica
Sigmoide Logarítmico	$f(n) = \frac{1}{1 + e^{-n}}$	
Sigmoide de Tangente Hiperbólica	$f(n) = \frac{e^n - e^{-n}}{e^n + e^{-n}}$	
Lineal	$f(n) = n$	
Escalón	$f(n) = \begin{cases} 1 & n \geq 0 \\ 0 & n < 0 \end{cases}$	
Escalón Simétrico	$f(n) = \begin{cases} 1 & n \geq 0 \\ -1 & n < 0 \end{cases}$	
Base Radial Gaussiana <sup>®</sup>	$f(n) = \exp\left[-\ n - c\ ^2 / d\right]$	
Competitiva	$f(n) = \begin{cases} 1 & \text{neurona con } \max(n) \\ 0 & \text{todas las demás neuronas} \end{cases}$	-

Tabla 4.1. Funciones de activación más utilizadas.

### 4.3. Arquitectura de una red neuronal.

La distribución de las neuronas en una red se realiza formando niveles o capas, habiendo por lo tanto tres tipos de capas de neuronas [3]:

- Entrada: son las que reciben los datos de provenientes del exterior.
- Ocultas: son internas a la red y no tienen contacto directo con el exterior. El número de capas ocultas puede variar desde cero hasta números elevados. Las conexiones de las neuronas de estas capas son las que nos dan las tipologías de redes neuronales que hay.
- Salida: transfieren información de la red hacia el exterior.

En general se pueden identificar tres clases diferentes de arquitecturas neuronales:

- Redes neuronales unicapa: como se ha mencionado antes las redes están organizadas por capas pues bien el caso más simple es el que solo tiene una capa con nodos computacionales:




Figura 4.2. Estructura de una red unicapa

- Redes neuronales multicapa: se caracterizan por tener una o más capas de neuronas ocultas:




Figura 4.3. Estructura de una red multicapa



- Redes neuronales recurrentes: se diferencia de las anteriores por tener al menos una retroalimentación:




Figura 4.4. Estructura de una red recurrente

#### 4.4. Conexión entre neuronas

La conectividad entre los nodos de una red neuronal está relacionada con la forma en que las salidas de las neuronas están canalizadas para convertirse en las entradas de las demás neuronas o de ellas mismas (lo que llamamos retroalimentación).

Estas conexiones tienen asociado un peso que es el encargado de que la red adquiera conocimiento. Una neurona recibe un conjunto de señales que la informan del estado de todas las neuronas a las que se encuentra conectada. La conexión de esta neurona con las demás está ponderada por unos pesos " $w_{ij}$ " (" $w_{ij}$ " representa la sinapsis entre la neurona " $i$ " y la neurona " $j$ "). La entrada a una neurona es la suma del producto de cada señal individual por el valor de la sinapsis (" $w_{ij}$ ") que conecta ambas neuronas:

(4.1)

" $W$ " es una matriz con todos los pesos  $w_{ij}$ , es un conjunto formado por elementos positivos, negativos y nulos: si " $w_{ij}$ " es positivo significa que la conexión entre las neuronas " $i$ ", " $j$ " es excitadora, si " $w_{ij}$ " es negativo significa que la conexión es inhibidora y si " $w_{ij}$ " es "0" no hay conexión entre ellas.

#### 4.5. Estructura de los datos.

En general se puede clasificar los datos de entrada a una red neuronal en dos grandes grupos:

- Concurrentes: se introducen a la red al mismo tiempo sin seguir una secuencia particular. El orden para este tipo de introducción de datos no es importante.

- Secuenciales: ocurren secuencialmente en el tiempo y el orden de los datos influye en el resultado de la red.

#### 4.6. Entrenamiento de una red neuronal.

La parte más importante de una Red Neuronal Artificial es el aprendizaje. Este determina el tipo de problema que será capaz de resolver. Los sistemas de aprendizaje están basados en ejemplos por lo que la capacidad de la red estará ligada al tipo de ejemplos que se dispone en el proceso de aprendizaje. Por lo que el conjunto de los ejemplos debe poseer las siguientes características:

- Ser significativos: debe de tener un número suficiente de ejemplos para que los pesos se adapten de forma eficaz.
- Ser representativo: ha de haber el mismo número de ejemplos de cada tipo, para que la red se adapte de forma general. Si se le introduce un mayor número de ejemplos de un cierto tipo la red se especializa en ese subconjunto de ejemplos y no lo hace de forma general.

El aprendizaje de una red trata fundamentalmente en ajustar los valores de los pesos precisos para todas sus conexiones, para ello se introducen todos los ejemplos y se ajustan los pesos hasta llegar a un cierto criterio de convergencia. El criterio de convergencia depende del problema y de la red y su finalización se puede determinar mediante:

- Un número fijo de ciclos: se decide cuantas veces serán introducidos los ejemplos, una vez hecho se detiene el proceso y se da por aceptada la resultante.
- Cuando el error desciende por debajo de una cantidad preestablecida: en primer lugar se define la función de error, se decide a priori un valor aceptable para ese error y el proceso solo se detiene cuando la red produzca un valor de error menor al prefijado.
- Cuando la modificación de los pesos sea irrelevante: hay modelos de redes neuronales en los cuales las conexiones van modificándose cada vez con menor intensidad, hasta que llega un momento en el que no se producen variaciones de los valores de los pesos. En ese momento la red converge y se detiene el proceso de aprendizaje.

Dependiendo del esquema de aprendizaje y del problema a resolver podemos distinguir tres tipos de aprendizajes:

- Supervisado: Las entradas se introducen como pares de datos, la entrada y su “target” asignado. “digo a la red que cuando introduzco esta entrada quiero esta salida”. De esta forma las salidas de la red se comparan con los “targets”

ajustando los pesos y las bias hasta que las salidas se acercan lo máximo a los “targets”.

- No supervisado: No se dispone de los “targets” por lo que las modificaciones de los pesos y la bias depende solo de las entradas a la red. Este tipo de redes se basa en agrupamientos de datos, separando las entradas en un número finito de clases.
- Por refuerzo: es una variable del aprendizaje supervisado en el que no se dispone de información concreta del error cometido por la red sino que simplemente se determina si la salida producida es o no adecuada.

#### **4.7. Tipos de redes neuronales.**

Existen muchos tipos de redes neuronales en la siguiente lista están los tipos más importantes y utilizados se han subrayado en **negrita** las redes que van a ser utilizadas en el presente proyecto fin de carrera:

- Perceptrón y perceptrón multicapas.
- Adaline.
- Memorias asociativas.
- Maquina de Bolzman.
- Maquina de Cauchy.
- Backpropagation (propagación hacia atrás).
- Redes de Elman.
- Redes de Hopfield.
- Red de contrapropagación.
- Redes de neuronas de base radial**
- Redes de neuronas de aprendizaje competitivo.
- Mapas Auto-organizados SOM (Mapas de Kohonen).**
- Crecimiento dinámico de células.
- Gas neuronal creciente.
- Redes ART (Adaptative Resonance theory).

#### 4.8. Redes de base radial [23].

Las redes de neuronas de base radial son redes multicapa con conexiones hacia adelante, se caracterizan porque están formadas por una única capa oculta y cada neurona de esta capa posee un carácter local. Este carácter local viene dado por el uso de las llamadas funciones de base radial, generalmente la función gaussiana, como función de activación. Las neuronas de la capa de salida realizan una combinación lineal de las activaciones de las neuronas ocultas. Se crearon con el objetivo de funcionar en tiempo real y son una de las redes más utilizadas en la diagnosis de defectos.

Se ha escogido este tipo de red neuronal para la realización de este proyecto en lugar de otros, por la rapidez que presentan a la hora del entrenamiento (supervisado) y por su fácil optimización, debido a que posee menos parámetros de diseño [23].

##### 4.8.1. Arquitectura de una red de base radial [3].

Una red neuronal de base radial está formada por tres capas de neuronas bien definidas (Figura 4.5). La capa de nodos de entrada, una única capa oculta y la capa de salida. La capa de entrada la componen un conjunto de neuronas que reciben las señales del exterior transmitiéndolas a la siguiente capa sin realizar ningún tipo de modificación sobre ellas. La capa oculta recibe las señales de la capa de entrada y realiza una transformación local y no lineal sobre dichas señales, esta capa es la única que realiza transformaciones no lineales. La capa de salida realiza una combinación lineal de las activaciones de las neuronas de la capa oculta, que además actúa como salida de red.




Figura 4.5. Estructura típica de la red RBF

En una red RBF excitada por un vector de entrada  $P(n) = [p_1(n), p_2(n), \dots, p_{n1}(n)]$ , que origina una capa de entrada con  $n_1$  neuronas, como muestra la figura m, las

neuronas de la capa de entrada no efectúan ninguna activación, simplemente propagan la información que reciben desde el exterior.

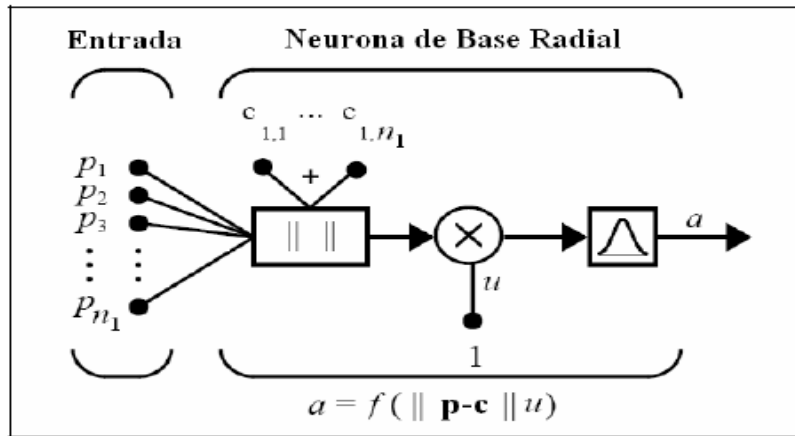


Figura 4.6. Propagación de información en una neurona de base radial

De manera general, entre la capa de entrada y la capa oculta no existen pesos, pero, si existe un procedimiento análogo que calcula la distancia euclídea entre el vector de entrada y su centroide (punto en el cual se centra la campana gaussiana de la función de activación), y lo multiplica por el umbral de la neurona. Este procedimiento resulta tal como muestra en la ecuación (4.2).

$$\|P(n) - C_i\| u_j^2 \quad \text{para } i = 1, 2, \dots, n_1 \quad \text{y para } j = 1, 2, \dots, n_2 \quad (4.2)$$

Donde  $C_i = (c_{i1}, c_{i2}, \dots, c_{in_2})$  es un vector que representa los centros de la función de base radial, y  $\| \cdot \|$  es la distancia euclídea del vector de entrada  $P(n)$  al centro  $C_i$ , definida como muestran las siguientes ecuaciones. El umbral de la capa oculta  $u_j^2$ , es igual para todas las neuronas de la misma capa (4.3).

$$\|P(n) - C_i\| = \left( \sum_{j=1}^{n_1} (p_j(n) - c_{ij})^2 \right)^{1/2} \quad (4.3)$$

Donde  $C$  toma el valor de la matriz traspuesta de  $P$ , tal como se indica a continuación en (4.4) y (4.5).

$$C_i = P(n)^T \quad (4.4)$$

$$u_j^2 = \frac{0.8326}{d_j} \text{ para } j=1, \dots, n_2. \quad (4.5)$$

El valor 0.8326 hace que la salida de la neurona sea 0.5 para una distancia euclídea igual a  $d_j$ . Donde  $d_j$  son números reales positivos, que representan la desviación, anchura o dilatación de la base radial. El programa utilizado toma por defecto un valor de 1.0, sin embargo, este factor podrá ser variado.

Para la capa oculta, sus activaciones dependen de la función de activación, y del vector de entradas a la red  $P(n)$ , y vienen dadas por la ecuación (4.6).

$$a_i^2(n) = f\left(\frac{\|P(n) - C_i\|}{d_i}\right) \quad \text{Para } i=1, 2, \dots, n_2. \quad (4.6)$$

Donde  $f$  es una función de activación de base radial, que suele adoptar tres formas distintas, la función gaussiana (4.7), la función inversa cuadrática (4.8), y finalmente, la función inversa multicuadrática, dada por la ecuación (4.9).

$$f(r) = e^{\left(\frac{-r^2}{2}\right)} \quad \text{Funcion Gaussiana} \quad (4.7)$$

$$f(r) = \frac{1}{1+r^2} \quad \text{Función inversa cuadrática} \quad (4.8)$$

$$f(r) = \frac{1}{\sqrt{1+r^2}} \quad \text{Función inversa multicuadrática} \quad (4.9)$$

En el contexto de las redes RBF, la función de activación más utilizada, es la función gaussiana, por tal motivo, la activación de las neuronas de la capa oculta, viene dada generalmente por ella (4.10).

$$a_i^2 = f_i(n) = e^{-\frac{\|P(n) - C_i\|^2}{2d_i^2}} = e^{-\frac{\sum_{j=1}^n (x_j(n) - c_{ij})^2}{2d_i^2}} \quad \text{para } i=1, 2, \dots, n_2. \quad (4.10)$$

Por último, las salidas de la red  $y_k(n)$ , vienen dadas por la expresión (4.11):

$$a_i^3 = y_k(n) = \sum_{i=1}^{n_2} w_{ik} a_i^2(n) + u_k^3 \text{ para } k=1, 2, \dots, n_3. \quad (4.11)$$

#### 4.8.2. Carácter local de las redes RBF.

Las funciones de base radial se caracterizan porque poseen un nivel máximo de activación para valores de entrada cercanos a cero y dicho nivel decrece a medida que la variable de entrada se aleja de dicho punto.

Se dice que la RBF son redes de carácter local, ya que, dado un patrón de entrada a la red, solo aquellas neuronas ocultas cuyos centros estén en la vecindad de dicho patrón se van a activar; el resto de las neuronas permanecerán inactivas o con un menor nivel de activación.

En la figura m, se observa la activación de dos neuronas vecinas para dos patrones de entrada,  $P(n)=[0,15 \ 0,45]$ .




Figura 4.7. Activación de dos neuronas de la capa oculta en redes RBF

Como puede observarse en la figura m. Para un valor de  $P(n)$  dado, existen dos valores de activación. Para el caso de la neurona representada con la curva discontinua, para un valor de 0,15 de entrada, presenta una activación de 1 (el valor máximo), mientras que la neurona vecina también se activa, pero en este caso, alcanza un valor de 0,22. La diferencia de activaciones de las dos neuronas para los dos valores de entrada, se detalla con el color azul (para la neurona de la izquierda), y rojo (para la neurona de la derecha). Cuanto más alejado esté el patrón de entrada del centro de la función de base radial de la neurona, la activación será de menor valor.

#### 4.8.3. Aprendizaje una red de base radial.

El algoritmo de aprendizaje utilizado es el que tiene disponible “Matlab” basado en un aprendizaje supervisado.

Dicho algoritmo, emplea una neurona en la capa oculta por cada patrón de entrada, y requiere un valor fijo de “ $d$ ” para efectuar el cálculo. Adicionalmente, los pesos que conectan las neuronas de la capa oculta con las de la capa de salida.

En este tipo de algoritmo, el error siempre es igual a cero, ya que se crea una neurona para que coincida con cada patrón de entrada.

Los parámetros de entrenamiento son mayoritariamente valores numéricos que relacionan al algoritmo de entrenamiento con la estructura de la red neuronal. Para una red RBF se consideran los siguientes parámetros de entrenamiento:

- **La normalización de los valores de entrada:** incrementa la estabilidad numérica del proceso de cálculo. Este parámetro se selecciona según las características de la función de activación utilizada. Para el caso de la función gaussiana, su rango es  $[0, 1]$ , por lo que resulta conveniente limitar las entradas de la red a este rango de valores.
- **La distribución de las entradas:** se efectúa con la determinación de distintos subgrupos. En este caso, sólo con “2” subgrupos el de entrenamiento y el de prueba.
- **La salida esperada de la red (S):** En la selección de este valor se considera que la activación de la función gaussiana, toma valores entre 0 y 1. Son los targets que se introducen a la red para que sepa el resultado que debe de obtener.
- **El valor de la anchura ( $d$ ):** Representa la desviación “standard” de la función de activación utilizada. Su selección se realiza cuidadosamente, ya que, influye en la activación de los patrones de entrada. Altos valores de “ $d$ ”, ocasionan el aumento del ancho de la “campana”, y pequeños valores de “ $d$ ”, resultan en campanas muy estrechas. En el presente proyecto, se ha utilizado un rango de valores de “ $d$ ”, entre 0 y 3, cada 0.01. Es decir, cada red será entrenada y probada con un valor de  $d$ . Dado por las ecuaciones (4.12) y (4.13).

(4.12)

(4.13)

- **El criterio de parada:** La red termina el proceso de aprendizaje cuando convergen los datos de entrada con los de salida, es decir cuando la red comienza a dar los resultados esperados según el criterio establecido con los targets asignados.



#### 4.9. Mapa auto-organizado (SOM) [1].

Las redes neuronales (SOM), son modelos que permiten separar en grupos las similitudes que existen dentro de un conjunto de datos de entrada. Los mapas auto-organizados son representaciones que aprenden a clasificar vectores de entrada según como se relacionan entre sí.

Este tipo de red posee un aprendizaje no supervisado competitivo. No existe ningún maestro externo que indique si la red neuronal está operando correcta o incorrectamente porque no se dispone de ninguna salida objetivo hacia la cual la red neuronal deba tender [23].

La red auto-organizada debe descubrir rasgos comunes, regularidades, correlaciones o categorías en los datos de entrada, e incorporarlos a su estructura interna de conexiones. Se dice, por tanto, que las neuronas deben auto-organizarse en función de los estímulos (datos) procedentes del exterior.

Se ha escogido este tipo de red para la realización del presente proyecto por la información que ofrece con respecto a la similitud de los datos de entrada (ninguna otra red ofrece mejor información en cuanto a los parecidos de los datos de entrada).

##### 4.9.1. Arquitectura de una red SOM.

Un modelo SOM está compuesto por dos capas de neuronas. La capa de entrada (formada por  $N$  neuronas, una por cada variable de entrada) se encarga de recibir y transmitir a la capa de salida la información procedente del exterior. La capa de salida (formada por  $M$  neuronas) es la encargada de procesar la información y formar el mapa de rasgos. Normalmente, las neuronas de la capa de salida se organizan en forma de mapa bidimensional como se muestra en la figura (4.8):




Figura 4.8. Estructura típica de una SOM

Las conexiones entre las dos capas que forman la red son siempre hacia delante, es decir, la información se propaga desde la capa de entrada hacia la capa de salida. Cada neurona de entrada “ $i$ ” está conectada con cada una de las neuronas de salida “ $j$ ” mediante un peso  $w_{ji}$ . De esta forma, las neuronas de salida tienen asociado un vector de pesos  $W_j$  llamado vector de referencia (o codebook), debido a que constituye el

vector prototipo (o promedio) de la categoría representada por la neurona de salida  $j$ . Así, el SOM define una proyección desde un espacio de datos en alta dimensión a un mapa bidimensional de neuronas.

El conjunto de variables de entrada a un mapa auto-organizado forma un vector real  $P$ .

$$P = [P_1, P_2, \dots, P_n]^T \in R^n \quad (4.14)$$

Entre las neuronas de la capa de salida, puede decirse que existen conexiones laterales de excitación e inhibición implícitas, pues aunque no estén conectadas, cada una de estas neuronas va a tener cierta influencia sobre sus vecinas. Esto se consigue a través de un proceso de competición entre las neuronas y de la aplicación de una función denominada de vecindad, que produce la topología (Figura 4.9) o estructura del mapa. Las topologías más frecuentes son la rectangular y la hexagonal.

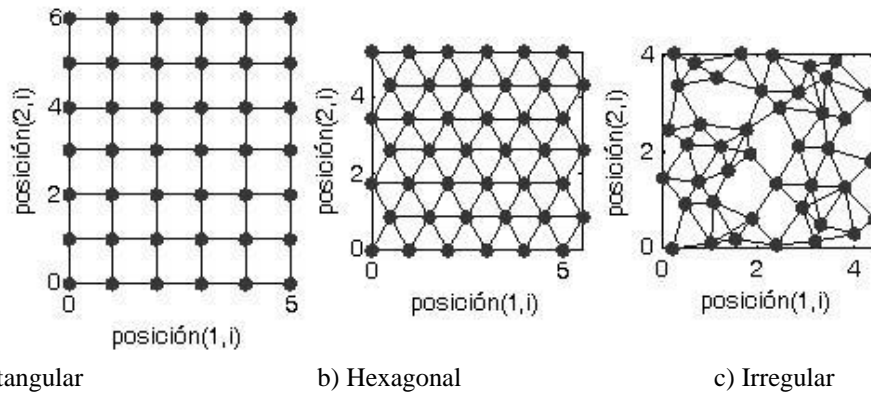


Figura 4.9. Topologías presentes en un mapa auto-organizado de siete filas por seis columnas, donde se muestra la ubicación de las neuronas

Las neuronas adyacentes pertenecen a una vecindad  $N_j$  de la neurona  $j$ . La topología y el número de neuronas permanece fijo desde el principio. El número de neuronas determina la suavidad de la proyección, lo cual influye en el ajuste y capacidad de generalización del SOM.

Cada neurona tiene asociado un peso  $w_i$  (también llamado modelo) de la misma dimensión que el vector de entrada.

$$w_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T \in R^n \quad (4.15)$$

El mapa auto-organizado realiza un mapeo del un conjunto de datos de entrada  $n$ -dimensionales ordenándolos en forma unidimensional o bidimensional. Para ello, la imagen de un vector de entrada,  $P$ , dentro del mapa auto-organizado estará dada como el elemento del vector  $w_i$  más próximo a  $P$ . Asumiendo una medida de distancia (dado por el índice  $c$ ) entre  $P$  y  $w_i$  denotada  $d(P, w_i)$ , se tiene.

$$c = \arg \min_i \|P, w_i\| \quad (4.16)$$

Para determinar cuál de los elementos del vector modelo (o vector de pesos)  $w_i$  se encuentra más cerca de los elementos de entrada, los pesos deben tener algún valor por lo que deben ser previamente inicializados. Dicha inicialización puede ser aleatoria, ya que la convergencia del mapa no depende de ella. Sin embargo, una inicialización con cierto tipo de regularidad, puede llegar a permitir que el mapa converja mucho más rápido. A continuación se realiza una comparación entre cada elemento del vector de entrada  $P$  y cada peso del vector  $w_i$ , donde la neurona cuyo peso resulte ser más similar a  $P$  según la medida de distancia previamente definida, será denominada neurona ganadora *BMU* (*Best Matching Unit*). Esta neurona ganadora es la que se activa según la función de activación previamente definida.

La vecindad  $N_{ci}[n]$  contiene todas las neuronas  $i$  que se encuentran en un radio  $d$  de la neurona ganadora  $c$  en el instante  $n$ , así:

$$N_{ci}[n] = \{i \mid d_{ci} \leq d\} \quad (4.17)$$

Para cada uno de los elementos de entrada se modifica tanto el peso de la neurona ganadora como los de aquellas contenidas dentro de la vecindad, siendo este ajuste proporcional a un factor  $\alpha$  llamado factor de aprendizaje (*learning factor*) con el fin de minimizar el error presente entre los pesos y el dato de entrada. El factor de aprendizaje y el radio de la vecindad determinan qué neuronas son modificadas y en qué grado.

Un mapa auto-organizado agrupa localmente parámetros similares de entrada gracias a la búsqueda de una distancia mínima. Para garantizar que dicha localización se mantenga y exista convergencia a lo largo del proceso, la vecindad disminuye su tamaño a medida que transcurre el proceso, de modo que  $N_{ci}[n] \rightarrow 0$  conforme  $n \rightarrow \infty$ . Asimismo, el factor de aprendizaje  $\alpha[n]$  va variando a lo largo del proceso

$$0 < \alpha[n] < 1; \quad \alpha[n] \rightarrow 0 \quad \text{as } n \rightarrow \infty \quad (4.18)$$

El tamaño inicial de la vecindad es un parámetro importante, ya que si no es lo suficientemente grande, el mapa auto-organizado no podrá ser organizado de manera global. En general, el radio inicial de la vecindad suele ser algo más de la mitad del diámetro de todo el mapa auto-organizado. La forma de la vecindad es independiente de la topología del mapa, aunque habitualmente se guarda una homogeneidad en este sentido (figura 5.9).




Figura 4.10. Ejemplo de vecindades topológicas

#### 4.9.2. Carácter local de las redes SOM.

Las ventajas de los mapas auto-organizativos radica es que son capaces de preservar la topología del espacio de los datos, proyectan datos altamente dimensionales a un esquema de representación de baja dimensión y tienen la habilidad de encontrar similitudes en los datos.

#### 4.9.3. Aprendizaje de una red SOM.

Durante la fase de entrenamiento, el SOM forma una red elástica que se pliega dentro de la nube de datos originales. El algoritmo controla la red de modo que tiende a aproximar la densidad de los datos. Los vectores de referencia del codebook se acercan a las áreas donde la densidad de datos es alta. Eventualmente unos pocos vectores del codebook están en áreas donde existe baja densidad de datos.

El entrenamiento de un mapa auto-organizado se divide en dos etapas principales:

- **Etapas de aprendizaje o de ordenamiento:** En esta etapa tanto el radio de la vecindad como el factor de aprendizaje se inician con sus valores máximos y decrecen hasta unos valores específicos determinados para la etapa de ajuste. Durante esta etapa, las neuronas se organizan de manera global dentro del espacio de datos de entrada con la misma topología con que están ordenadas y relacionadas entre sí. Al finalizar esta etapa, se comienza la etapa de ajuste.
- **Etapas de ajuste:** Se caracteriza porque el radio de la vecindad solo permite incluir a neuronas muy cercanas a la neurona ganadora (activa). Mientras tanto, el factor de aprendizaje se inicia también en un valor pequeño y decrece muy lentamente. De manera conjunta, estos parámetros permiten un ajuste fino de la ubicación de las neuronas, al tiempo que mantiene estable el ordenamiento alcanzado durante la etapa de aprendizaje. El número de ciclos de entrenamiento durante esta etapa puede llegar a ser cientos de veces mayor que los utilizados durante la etapa de ordenamiento.

El algoritmo de aprendizaje seguido por una red SOM es el siguiente:

- En primer lugar, Un vector  $x$  es seleccionado al azar del conjunto de datos y se calcula su distancia (similitud) a los vectores del codebook, usando, por ejemplo, la distancia euclídea (4.19):

(4.19)

- Una vez que se ha encontrado el vector más próximo o BMU (best matching unit) el resto de vectores del codebook es actualizado. El BMU y sus vecinos (en sentido topológico) se mueven cerca del vector  $x$  en el espacio de datos. La magnitud de dicha atracción está regida por la tasa de aprendizaje.

Mientras se va produciendo el proceso de actualización y nuevos vectores se asignan al mapa, la tasa de aprendizaje decrece gradualmente hacia cero. Junto con ella también decrece el radio de vecindad. La regla de actualización para el vector de referencia “ $i$ ” viene dado es la siguiente:

(4.20)

- Los pasos 1 y 2 se van repitiendo hasta que el entrenamiento termina. El número de pasos de entrenamiento se debe fijar antes a priori, para calcular la tasa de convergencia de la función de vecindad y de la tasa de aprendizaje.
- Una vez terminado el entrenamiento, el mapa ha de ordenarse en sentido topológico:  $n$  vectores topológicamente próximos se aplican en  $n$  neuronas adyacentes o incluso en la misma neurona.

## Capítulo 5.

### RESULTADOS DE LAS REDES SOM Y RBF

#### 5.1. Entradas a las redes.

En el presente capítulo se exponen los resultados obtenidos, en la clasificación de las fallas de un CTC, de las dos redes neuronales utilizadas para dicha clasificación.

En primer lugar se exponen en la tabla 5.1 los vectores de entrada a las redes, los cuales están formados por: “5” DTs (capítulo “2”) y “6” energías (capítulo “2”)

DT <sub>1</sub>	DT <sub>2</sub>	DT <sub>3</sub>	DT <sub>4</sub>	DT <sub>5</sub>	Energ <sub>1</sub>	Energ <sub>2</sub>	Energ <sub>3</sub>	Energ <sub>4</sub>	Energ <sub>5</sub>	Energ <sub>6</sub>
-----------------	-----------------	-----------------	-----------------	-----------------	--------------------	--------------------	--------------------	--------------------	--------------------	--------------------

Tabla 5.1. Vector general de entrada a las redes.

Para cada tipo de defecto se tiene una estructura diferente del vector anterior de entrada a la red, (para ciertos defectos no aparecen ciertos impulsos), en las siguientes tablas se puede ver cuáles de estos indicadores faltan para cada tipo de defecto (se ha asignado el valor “0” para indicar a las redes la falta de estos):

##### 1. Buen estado:

DT <sub>1</sub>	DT <sub>2</sub>	DT <sub>3</sub>	DT <sub>4</sub>	DT <sub>5</sub>	Energ <sub>1</sub>	Energ <sub>2</sub>	Energ <sub>3</sub>	Energ <sub>4</sub>	Energ <sub>5</sub>	Energ <sub>6</sub>
-----------------	-----------------	-----------------	-----------------	-----------------	--------------------	--------------------	--------------------	--------------------	--------------------	--------------------

Tabla 5.2. Vector correspondiente a los ensayos en buen estado

##### 2. Holgura en el anclaje de las barras del selector a la estructura.

DT <sub>1</sub>	DT <sub>2</sub>	-	-	DT <sub>5</sub>	Energ <sub>1</sub>	Energ <sub>2</sub>	Energ <sub>3</sub>	-	Energ <sub>5</sub>	Energ <sub>6</sub>
-----------------	-----------------	---	---	-----------------	--------------------	--------------------	--------------------	---	--------------------	--------------------

Tabla 5.3. Vector correspondiente a los ensayos de holgura

3. Contactos fijos del selector flojos.

DT <sub>1</sub>	DT <sub>2</sub>	-	-	DT <sub>5</sub>	Energ <sub>1</sub>	Energ <sub>2</sub>	Energ <sub>3</sub>	-	Energ <sub>5</sub>	Energ <sub>6</sub>
-----------------	-----------------	---	---	-----------------	--------------------	--------------------	--------------------	---	--------------------	--------------------

Tabla 5.4. Vector correspondiente a contactos desgastados

4. Muelles de los contactos móviles sin la tensión adecuada.

DT <sub>1</sub>	DT <sub>2</sub>	-	-	DT <sub>5</sub>	Energ <sub>1</sub>	Energ <sub>2</sub>	Energ <sub>3</sub>	-	Energ <sub>5</sub>	Energ <sub>6</sub>
-----------------	-----------------	---	---	-----------------	--------------------	--------------------	--------------------	---	--------------------	--------------------

Tabla 5.5. Vector correspondiente a muelles sin tensión adecuada.

5. Barra de anclaje del selector partida (contactos fijos de llegada inexistentes).

-	-	-	DT <sub>4</sub>	DT <sub>5</sub>	Energ <sub>1</sub>	-	-	Energ <sub>4</sub>	Energ <sub>5</sub>	Energ <sub>6</sub>
---	---	---	-----------------	-----------------	--------------------	---	---	--------------------	--------------------	--------------------

Tabla 5.6. Vector correspondiente a contactos fijos de llegada inexistente

6. Barra de anclaje del selector partida (contactos fijos de partida inexistentes).

-	-	-	-	-	Energ <sub>1</sub>	-	-	-	-	Energ <sub>6</sub>
---	---	---	---	---	--------------------	---	---	---	---	--------------------

Tabla 5.7. Vector correspondiente a contactos fijos de partida inexistente

7. Contactos fijos de llegada del selector desgastados.

DT <sub>1</sub>	DT <sub>2</sub>	DT <sub>3</sub>	DT <sub>4</sub>	DT <sub>5</sub>	Energ <sub>1</sub>	Energ <sub>2</sub>	Energ <sub>3</sub>	Energ <sub>4</sub>	Energ <sub>5</sub>	Energ <sub>6</sub>
-----------------	-----------------	-----------------	-----------------	-----------------	--------------------	--------------------	--------------------	--------------------	--------------------	--------------------

Tabla 5.8. Vector correspondiente a contactos del selector desgastados

8. Amortiguación en el carro de accionamiento en el trinquete.

DT <sub>1</sub>	-	-	-	DT <sub>5</sub>	Energ <sub>1</sub>	Energ <sub>2</sub>	-	-	Energ <sub>5</sub>	Energ <sub>6</sub>
-----------------	---	---	---	-----------------	--------------------	--------------------	---	---	--------------------	--------------------

Tabla 5.9. Vector correspondiente a amortiguación en el trinquete

9. Amortiguación en el carro de accionamiento en el listón.

-	-	-	-	DT <sub>5</sub>	Energ <sub>1</sub>	-	-	-	Energ <sub>5</sub>	Energ <sub>6</sub>
---	---	---	---	-----------------	--------------------	---	---	---	--------------------	--------------------

Tabla 5.10. Vector correspondiente a amortiguación en el listón.

10. Amortiguación en el carro de accionamiento en el listón-gatillo.

-	-	-	-	-	Energ <sub>1</sub>	-	-	-	-	Energ <sub>6</sub>
---	---	---	---	---	--------------------	---	---	---	---	--------------------

Tabla 5.11. Vector correspondiente a amortiguación en el listón-gatillo.

## 5.2. Estudio estadístico.

Para asegurar que los datos de entrada a las redes son fiables se ha realizado un estudio estadístico de los “48” ensayos de cada clasificación. En este se han obtenido la media, la desviación típica y el Coeficiente de variación de variación (Coeficiente de Pearson).

Con este estudio se demuestra la homogeneidad de los datos para asegurar que las redes clasificarán los ensayos que presenten los mismos patrones.

He tomado cuarenta y ocho (“48”) ensayos de cada defecto con el fin de mejorar la clasificación de las redes utilizando treinta y seis de ellos para el entrenamiento y doce para la clasificación.

En las siguientes tablas podemos ver las variables estadísticas de cada una de las clasificaciones.

En la tabla 5.12 se puede observar que el Coeficiente de Pearson es pequeño lo que indica que los datos de los ensayos son homogéneos, y por consiguiente buenos para las entradas de las redes:



<b>BUEN ESTADO</b>					
DTs	T2-T1	T3-T2	T4-T3	T5-T4	T6-T5
MEDIA	0,6499	3,0568	0,1301	0,5519	1,2506
DESVIACION TIPICA	0,0332	0,0406	0,0164	0,0517	0,0425
COEFICIENTE DE PEARSON	0,0511	0,0133	0,1262	0,0938	0,0340
<b>HOLGURA</b>					
DTs	T2-T1	T3-T2	T4-T3	T5-T4	T6-T5
MEDIA	0,6297	3,0966	-	-	1,169
DESVIACION TIPICA	0,0187	0,0108	-	-	0,1931
COEFICIENTE DE PEARSON	0,0297	0,0035	-	-	0,1652
<b>CONTACTOS FLOJOS</b>					
DTs	T2-T1	T3-T2	T4-T3	T5-T4	T6-T5
MEDIA	0,6488	3,0943	-	-	1,2298
DESVIACION TIPICA	0,0178	0,0412	-	-	0,0128
COEFICIENTE DE PEARSON	0,0275	0,0133	-	-	0,0104
<b>MUELLES SIN TENSION</b>					
DTs	T2-T1	T3-T2	T4-T3	T5-T4	T6-T5
MEDIA	0,6547	3,1144	-	-	1,1975
DESVIACION TIPICA	0,0158	0,0447	-	-	0,0727
COEFICIENTE DE PEARSON	0,0239	0,0143	-	-	0,0607
<b>BARRA LLEGADA INEXISTENTE</b>					
DTs	T2-T1	T3-T2	T4-T3	T5-T4	T6-T5
MEDIA	-	-	-	0,6361	1,2832
DESVIACION TIPICA	-	-	-	0,0279	0,0268
COEFICIENTE DE PEARSON	-	-	-	0,0438	0,0209
<b>BARRA PARTIDA INEXISTENTE</b>					
DTs	T2-T1	T3-T2	T4-T3	T5-T4	T6-T5
MEDIA	-	-	-	-	-
DESVIACION TIPICA	-	-	-	-	-
COEFICIENTE DE PEARSON	-	-	-	-	-
<b>CONTACTOS DESGASTADOS</b>					
DTs	T2-T1	T3-T2	T4-T3	T5-T4	T6-T5
MEDIA	1,1356	2,4422	0,7332	1,1856	0,6525
DESVIACION TIPICA	0,0203	0,0073	0,0202	0,2272	0,0568
COEFICIENTE DE PEARSON	0,0179	0,003	0,0275	0,1916	0,087
<b>AMORTIGUACION TRINQUETE</b>					
DTs	T2-T1	T3-T2	T4-T3	T5-T4	T6-T5
MEDIA	0,5632	-	-	-	1,1195
DESVIACION TIPICA	0,0123	-	-	-	0,1132
COEFICIENTE DE PEARSON	0,0218	-	-	-	0,1011
<b>AMORTIGUACION LISTON</b>					
DTs	T2-T1	T3-T2	T4-T3	T5-T4	T6-T5
MEDIA	-	-	-	-	1,4414
DESVIACION TIPICA	-	-	-	-	0,0577
COEFICIENTE DE PEARSON	-	-	-	-	0,04
<b>AMORTIGUACION LISTON-GATILLO</b>					
DTs	T2-T1	T3-T2	T4-T3	T5-T4	T6-T5
MEDIA	-	-	-	-	-
DESVIACION TIPICA	-	-	-	-	-
COEFICIENTE DE PEARSON	-	-	-	-	-

Tabla 5.12. Estudio estadístico de los indicadores DTs

En cuanto a la tabla de energías los Coeficientes de Pearson son también bajos por lo que demuestran la homogeneidad de los datos:

BUEN ESTADO						
ENERGIA	Imp 1	Imp 2	Imp 3	Imp 4	Imp 5	Imp 6
MEDIA	0,002	0,0001	0,000049	0,00003	0,0063	0,0007
DESVIACION TIPICA	0,0004	0,00002	0,000025	0,000016	0,0012	0,0011
COEFICIENTE DE PEARSON	0,2115	0,213	0,5102	0,5122	0,188	1,6769
HOLGURA						
ENERGIA	Imp 1	Imp 2	Imp 3	Imp 4	Imp 5	Imp 6
MEDIA	0,0015	0,000054	0,000016	-	0,0058	0,00037
DESVIACION TIPICA	0,00036	0,000015	0,000008	-	0,0005	0,00017
COEFICIENTE DE PEARSON	0,243	0,2852	0,5225	-	0,0943	0,4521
CONTACTOS FLOJOS						
ENERGIA	Imp 1	Imp 2	Imp 3	Imp 4	Imp 5	Imp 6
MEDIA	0,0021	0,000038	0,00014	-	0,0075	0,00041
DESVIACION TIPICA	0,0017	0,000017	0,00072	-	0,0022	0,00024
COEFICIENTE DE PEARSON	0,8134	0,4645	5,2392	-	0,2942	0,59108
MUELLES SIN TENSION						
ENERGIA	Imp 1	Imp 2	Imp 3	Imp 4	Imp 5	Imp 6
MEDIA	0,0012	1,15E-05	0,000015	-	0,00425	0,00026
DESVIACION TIPICA	0,0005	1,30E-06	0,000016	-	0,00021	0,00024
COEFICIENTE DE PEARSON	0,4508	0,1183	1,046	-	0,04864	0,7859
BARRA LLEGADA INEXISTENTE						
ENERGIA	Imp 1	Imp 2	Imp 3	Imp 4	Imp 5	Imp 6
MEDIA	0,0014	-	-	0,00043	0,00522	0,00035
DESVIACION TIPICA	0,0002	-	-	0,00025	0,00087	0,00014
COEFICIENTE DE PEARSON	0,1643	-	-	0,57993	0,16825	0,39499
BARRA PARTIDA INEXISTENTE						
ENERGIA	Imp 1	Imp 2	Imp 3	Imp 4	Imp 5	Imp 6
MEDIA	0,0017	-	-	-	-	0,0047
DESVIACION TIPICA	0,0006	-	-	-	-	0,0013
COEFICIENTE DE PEARSON	0,3326	-	-	-	-	0,2863
CONTACTOS DESGASTADOS						
ENERGIA	Imp 1	Imp 2	Imp 3	Imp 4	Imp 5	Imp 6
MEDIA	0,0013	0,00044	0,00023	0,0078	0,0222	0,0108
DESVIACION TIPICA	0,0003	0,00013	0,00025	0,0161	0,0188	0,0187
COEFICIENTE DE PEARSON	0,2314	0,30039	1,07239	2,0611	0,8435	1,64
AMORTIGUACION TRINQUETE						
ENERGIA	Imp 1	Imp 2	Imp 3	Imp 4	Imp 5	Imp 6
MEDIA	0,0033	0,000047	-	-	0,0043	2,63E-05
DESVIACION TIPICA	0,0013	0,000017	-	-	0,0021	8,60E-06
COEFICIENTE DE PEARSON	0,3922	0,363	-	-	0,4943	0,3272
AMORTIGUACION LISTON						
ENERGIA	Imp 1	Imp 2	Imp 3	Imp 4	Imp 5	Imp 6
MEDIA	0,0029	-	-	-	0,0032	0,000034
DESVIACION TIPICA	0,0009	-	-	-	0,0013	0,000017
COEFICIENTE DE PEARSON	0,3042	-	-	-	0,4281	0,5098
AMORTIGUACION LISTON-GATILLO						
ENERGIA	Imp 1	Imp 2	Imp 3	Imp 4	Imp 5	Imp 6
MEDIA	0,0027	-	-	-	-	0,0068
DESVIACION TIPICA	0,0009	-	-	-	-	0,0037
COEFICIENTE DE PEARSON	0,3227	-	-	-	-	0,548

Tabla 5.13. Estudio estadístico de los indicadores de energías

### 5.3. Resultado de las redes.

Para trabajar con las redes a cada “defecto” se le ha asignado una letra:

- Buen estado-**B**
- Holgura en el anclaje de las barras del selector a la estructura-**H**.
- Contactos fijos del selector flojos-**C**.
- Muelles de los contactos móviles sin la tensión adecuada-**T**.
- Barra de anclaje del selector partida (contactos fijos de llegada inexistentes)-**P**.
- Barra de anclaje del selector partida (contactos fijos de partida inexistentes)-**Q**.
- Contactos fijos de llegada del selector desgastados-**D**.
- Amortiguación en el carro de accionamiento en el trinquete-**L**.
- Amortiguación en el carro de accionamiento en el listón-**A**.
- Amortiguación en el carro de accionamiento en el listón-gatillo-**G**.

#### 5.3.1. Resultados “10” clasificaciones.

En la tabla 5.14 se ven los datos del resultado del entrenamiento de la Red de base radial para “10” clasificaciones

Nº neuronas	10	14	18	22	26	30	34	38
SPREAD	2,75	2,97	2,13	2,37	1,55	2,2	2,46	2,08
% ACIERTO B	100	100	100	100	100	100	100	100
% ACIERTO C	91,6667	47,2222	77,7778	86,1111	83,3333	91,6667	86,1111	77,7778
% ACIERTO H	66,6667	94,4444	94,4444	83,3333	88,8889	83,3333	88,8889	88,8889
% ACIERTO T	61,1111	100	100	100	100	100	100	100
% ACIERTO D	100	100	100	100	100	100	100	100
% ACIERTO A	100	100	100	100	100	100	100	100
% ACIERTO L	100	100	100	100	100	100	100	100
% ACIERTO G	11,1111	11,1111	11,1111	55,5556	55,5556	55,5556	88,8889	88,8889
% ACIERTO P	100	100	100	100	100	100	100	100
% ACIERTO Q	100	100	100	88,8889	100	88,8889	88,8889	88,8889
% ACIERTO GLOBAL	83,0556	85,5556	88,3333	91,3889	91,6667	91,9444	91,9444	94,4444

Nº neuronas	42	46	50	54	58	62	66	70
SPREAD	2,08	0,88	0,88	0,79	0,69	0,69	0,69	0,69
% ACIERTO B	100	100	100	100	100	100	100	100
% ACIERTO C	77,7778	86,1111	86,1111	86,1111	86,1111	86,1111	86,1111	86,1111
% ACIERTO H	88,8889	94,4444	94,4444	94,4444	94,4444	94,4444	94,4444	94,4444
% ACIERTO T	100	100	100	100	100	100	100	100
% ACIERTO D	100	100	100	100	100	100	100	100
% ACIERTO A	100	100	100	100	100	100	100	100
% ACIERTO L	100	100	100	100	100	100	100	100
% ACIERTO G	88,8889	88,8889	88,8889	88,8889	88,8889	88,8889	88,8889	88,8889
% ACIERTO P	100	100	100	100	100	100	100	100
% ACIERTO Q	88,8889	88,8889	88,8889	88,8889	88,8889	88,8889	88,8889	88,8889
% ACIERTO GLOBAL	94,4444	95,8333	95,8333	95,8333	95,8333	95,8333	95,8333	95,8333

Tabla 5.14. Resultados del entrenamiento de la RBF para “10” clasificaciones

En la tabla 5.15 se ven los datos del resultado de la clasificación del Test de la red de base radial para “10” clasificaciones:

Nº neuronas	10	14	18	22	26	30	34	38
SPREAD	2,52	2,41	1,84	1,84	0,74	0,63	0,63	0,58
% ACIERTO B	100	100	100	100	100	100	100	100
% ACIERTO C	8,3333	16,6667	91,6667	83,3333	91,6667	91,6667	91,6667	91,6667
% ACIERTO H	91,6667	75	83,3333	91,6667	91,6667	91,6667	91,6667	91,6667
% ACIERTO T	75	100	100	100	100	100	100	100
% ACIERTO D	100	100	100	100	100	100	100	100
% ACIERTO A	100	100	100	100	100	100	100	100
% ACIERTO L	100	100	100	100	100	100	100	100
% ACIERTO G	33,3333	66,6667	66,6667	100	100	100	100	100
% ACIERTO P	100	100	100	100	100	100	100	100
% ACIERTO Q	100	100	100	100	100	100	100	100
% ACIERTO GLOBAL	80,8333	85,8333	93,3333	96,6667	97,5	97,5	97,5	97,5

Nº neuronas	42	46	50	54	58	62	66	70
SPREAD	0,57	0,54	0,54	0,54	0,59	0,59	0,59	0,32
% ACIERTO B	100	100	100	100	100	100	100	100
% ACIERTO C	91,6667	91,6667	91,6667	91,6667	91,6667	91,6667	91,6667	100
% ACIERTO H	91,6667	91,6667	91,6667	91,6667	91,6667	91,6667	91,6667	91,6667
% ACIERTO T	100	100	100	100	100	100	100	100
% ACIERTO D	100	100	100	100	100	100	100	100
% ACIERTO A	100	100	100	100	100	100	100	100
% ACIERTO L	100	100	100	100	100	100	100	100
% ACIERTO G	100	100	100	100	100	100	100	100
% ACIERTO P	100	100	100	100	100	100	100	100
% ACIERTO Q	100	100	100	100	100	100	100	100
% ACIERTO GLOBAL	97,5	97,5	97,5	97,5	98,3333	98,3333	98,3333	99,1667

Tabla 5.15. Resultados de la prueba de la RBF para “10” clasificaciones.

Los resultados óptimos, tanto para entrenamiento como para el Test, han sido obtenidos para un número de “70” neuronas. En las tablas están coloreados de Rojo, de todas formas se exponen en la tabla 5.16 para contrastar la información:

Nº neuronas	70	70
	Entrenamiento Op =	Ensayo Op =
SPREAD	0,69	0,32
% ACIERTO B	100	100
% ACIERTO C	86,1111	100
% ACIERTO H	94,4444	91,6667
% ACIERTO T	100	100
% ACIERTO D	100	100
% ACIERTO A	100	100
% ACIERTO L	100	100
% ACIERTO G	88,8889	100
% ACIERTO P	100	100
% ACIERTO Q	88,8889	100
% ACIERTO GLOBAL	95,8333	99,1667

Tabla 5.16. Resultados óptimos de entrenamiento y prueba de la RBF.

Los resultados obtenidos son como se puede comprobar excelentes, se debe en su mayoría a que los indicadores de diagnóstico utilizados son muy buenos y la red los diferencia perfectamente.

En la columna correspondiente al entrenamiento se ve que hay una clasificación del 86%, 94%, 89% y 89% que son muy buenas pero menores a la clasificación del resto de los defectos esto se debe a que esos defectos presentan unos indicadores de diagnóstico muy parecidos por lo que la red puede llegar a confundirlos.

En cuanto al Test la clasificación es prácticamente perfecta, salvo por el 92% de clasificación del defecto Holgura en el anclaje de las barras del selector a la estructura, que seguramente por su parecido con otros defectos haya algún ensayo que haya desechado.

En la figura 5.1 se ve la evolución de la red tanto en el entrenamiento como en la prueba (Test):




Figura 5.1. Evolución del entrenamiento y la prueba Vs spread para “10” clasificaciones

En el gráfico puede verse que tanto el entrenamiento como la prueba oscilan desde valores muy buenos (100% de clasificación) a valores muy malos (25% de clasificación en entrenamiento y hasta del 0% en la prueba) para ciertos valores del ancho de base (spread). Esto se debe a que para valores de ancho de campana la red

confunde los defectos que se parecen y hace que el acierto sea muy pequeño incluso hasta “0”.

Los resultados de la red SOM para “10” clasificaciones son los siguientes y se han obtenido a partir de una red no supervisada:




Figura 5.2. U-matriz de la SOM para “10”clasificaciones

La U-matriz de clasificación indica que las neuronas ganadoras de distintos defectos están muy próximas, eso se debe a que la red confunde estos defectos debido a su similitud.

La red confunde los defectos de H (-Holgura en el anclaje de las barras del selector a la estructura), C (Contactos fijos del selector flojos) y T (Muelles de los contactos móviles sin la tensión adecuada) que los clasifica en la esquina superior derecha de la U-matriz, confunde también los defectos Q (Barra de anclaje del selector partida (contactos fijos de partida inexistentes)) y los G (Amortiguación en el carro de accionamiento en el listón-gatillo) que los clasifica en la parte inferior izquierda.



Se van a agrupar los defectos que la red confunde con el fin de mejorar la clasificación.

-El primero es la unión de “H”, “C” y “T”, se le ha llamado “U”. Para formar este grupo se han tomado “48” ensayos al azar de los “144” que forman los tres defectos.

-El segundo es la unión de “Q” y “G”, se le ha llamado “V”, está formado por “48” ensayos de los “96” totales.




Figura 5.3. Agrupación de los defectos



### 5.3.2. Resultados “7” clasificaciones.

Una vez agrupados los defectos que la red confunde (aquellos que tienen similares indicadores de diagnóstico) se ha programado otras dos redes pero esta vez con siete defectos:

- Buen estado-**B**
- Unión de “H”, ”C” y “T”-**U**
- Barra de anclaje del selector partida (contactos fijos de llegada inexistentes)-**P**.
- Contactos fijos de llegada del selector desgastados-**D**.
- Amortiguación en el carro de accionamiento en el trinquete-**L**.
- Amortiguación en el carro de accionamiento en el listón-**A**.
- Unión de “G” y”-**V**.

Los datos de la tabla 5.17 son el resultado del entrenamiento de la Red de base radial para “7” clasificaciones:

Nº neuronas	10	14	18	22	26	30	34	38
SPREAD	1,24	0,35	0,19	0,18	0,17	0,16	0,14	0,13
% ACIERTO B	100	100	100	100	100	100	100	100
% ACIERTO U	100	100	100	100	100	100	100	100
% ACIERTO L	100	100	100	100	100	100	100	100
% ACIERTO D	100	100	100	100	100	100	100	100
% ACIERTO A	100	100	100	100	100	100	100	100
% ACIERTO P	94,4444	94,4444	94,4444	94,4444	94,4444	94,4444	94,4444	94,4444
% ACIERTO V	100	100	100	100	100	100	100	100
% ACIERTO GLOBAL	99,2063	99,2063	99,2063	99,2063	99,2063	99,2063	99,2063	99,2063

Nº neuronas	42	46	50	54	58	62	66	70
SPREAD	0,12	0,11	0,1	0,1	0,1	0,1	0,1	0,1
% ACIERTO B	100	100	100	100	100	100	100	100
% ACIERTO U	100	100	100	100	100	100	100	100
% ACIERTO L	100	100	100	100	100	100	100	100
% ACIERTO D	100	100	100	100	100	100	100	100
% ACIERTO A	100	100	100	100	100	100	100	100
% ACIERTO P	94,4444	94,4444	94,4444	94,4444	94,4444	94,4444	94,4444	94,4444
% ACIERTO V	100	100	100	100	100	100	100	100
% ACIERTO GLOBAL	99,2063	99,2063	99,2063	99,2063	99,2063	99,2063	99,2063	99,2063

Tabla 5.17. Resultados del entrenamiento de la RBF para “7” clasificaciones

Como se puede observar los resultados son excelentes para cualquier Spread y cualquier número de neuronas, como para la clasificación de “10” defectos los mejores resultados fueron para un número de “70” neuronas se ha tomado como óptimo ese valor en esta clasificación.

Los datos de la tabla 5.18 son el resultado de la clasificación del Test de la red de base radial para “7” clasificaciones:

Nº neuronas	10	14	18	22	26	30	34	38
SPREAD	0,39	0,19	0,18	0,2	0,17	0,17	0,14	0,14
% ACIERTO B	100	100	100	100	100	100	100	100
% ACIERTO U	100	100	100	100	100	100	100	100
% ACIERTO L	100	100	100	100	100	100	100	100
% ACIERTO D	100	100	100	100	100	100	100	100
% ACIERTO A	100	100	100	100	100	100	100	100
% ACIERTO P	100	100	100	100	100	100	100	100
% ACIERTO V	100	100	100	100	100	100	100	100
% ACIERTO GLOBAL	100	100	100	100	100	100	100	100

Nº neuronas	42	46	50	54	58	62	66	70
SPREAD	0,19	0,2	0,22	0,2	0,21	0,2	0,2	0,2209
% ACIERTO B	100	100	100	100	100	100	100	100
% ACIERTO U	100	100	100	100	100	100	100	100
% ACIERTO L	100	100	100	100	100	100	100	100
% ACIERTO D	100	100	100	100	100	100	100	100
% ACIERTO A	100	100	100	100	100	100	100	100
% ACIERTO P	100	100	100	100	100	100	100	100
% ACIERTO V	100	100	100	100	100	100	100	100
% ACIERTO GLOBAL	100	100	100	100	100	100	100	100

Tabla 5.18. Resultados de la prueba de la RBF para “7” clasificaciones

El resultado del test para “7” defectos es perfecto, la red clasifica con un 100 % de precisión. Al igual que en el entrenamiento se ha tomado como resultado óptimo el correspondiente a “70” neuronas por haber sido el óptimo en la red de “10” clasificaciones. Puede observarse en la tabla 5.19.

Nº neuronas	70	70
	Entrenamiento Op =	Ensayo Op =
SPREAD	0,1	0,2209
% ACIERTO B	100	100
% ACIERTO U	100	100
% ACIERTO L	100	100
% ACIERTO D	100	100
% ACIERTO A	100	100
% ACIERTO P	94,4444	100
% ACIERTO V	100	100
% ACIERTO GLOBAL	99,2063	100

Tabla 5.19. Resultados óptimos de entrenamiento y la prueba de la RBF

La modificación que se ha realizado uniendo los defectos que la red confundía ha hecho, que los rendimientos de esta sean perfectos clasificando todos los defectos al 100%.

En la figura 5.4 se ve la evolución de la red, tanto el entrenamiento como la prueba (Test):





Figura 5.4. Evolución del entrenamiento y la prueba Vs spread para “7” clasificaciones

En la figura 5.4 se puede observar que la red no tiene oscilaciones como ocurría en el caso de “10” clasificaciones, y que a partir de un spread de “0,2” la red clasifica con una eficiencia del 100 %.

Los resultados de la SOM para “7” clasificaciones se pueden observar en la figura 5.5:



SOM 08-Jun-2010

Figura 5.5. U-matriz de la SOM para “7”clasificaciones

La figura 5.5 muestra la U-matriz de “7” clasificaciones. Puede verse que aún existen varias neuronas ganadoras para cada defecto pero claramente existen “7” regiones que separan los diferentes defectos.

Se ha conseguido una clara mejora de la clasificación con respecto a la clasificación inicial de “10” defectos, en este caso los ensayos tomados al azar de los defectos fusionados son reconocidos como un solo defecto.

## Capítulo 6.

# CONCLUSIONES Y TRABAJOS FUTUROS.

## 6.1. CONCLUSIONES.

El estudio realizado en el presente proyecto fin de carrera sobre la clasificación de las fallas en un CTC ha demostrado **que los indicadores de diagnóstico que se han tomado a partir del algoritmo de Rivas son homogéneos y constantes**, para cada cierto tipo de defecto, pudiendo asegurar que cada defecto presenta una estructura de indicadores diferente.

Dichos indicadores han sido introducidos en las dos redes, es decir, que los vectores de entrada han sido los mismos. Se ha demostrado que para los mismos vectores de entrada, **la red de base Radial es más eficiente que la red SOM** (ya se vio en el capítulo “3”), llegando a eficiencias del “100%” para ciertos valores de “spread”. Por el contrario la red SOM nos ofrece una gran información sobre el parecido de los defectos, lo cual hace que se tomen las decisiones pertinentes para las agrupaciones. Estas agrupaciones han conseguido una gran eficiencia de las redes a cambio de varios defectos (no se puede conocer la avería exacta de las agrupaciones así por ejemplo cuando se tiene un defecto de la unión llamada “U” no podemos saber si se debe a “Holgura en el anclaje de las barras del selector a la estructura”; a “Contactos fijos del selector flojos”; o a “Muelles de los contactos móviles sin la tensión adecuada”). **Por lo que la conclusión es que rechazamos información para poder asegurar clasificación.**

## 6.2. TRABAJOS FUTUROS.

Tanto en este proyecto como en la tesis en la que está basado [1], se centran en la detección de los defectos del cambiador cuando estos ya han sido producidos. Un trabajo futuro sería el estudio de otros indicadores o incluso el proceso de transformación de los actuales indicadores (los utilizados en este proyecto) con el fin de identificar cuando va a ocurrir un fallo y ponerle remedio antes de que este ocurra.



## **AGRADECIMIENTOS.**

Quiero agradecer a mis tutores, Edwin Rivas-Trujillo y Alberto Ordoñez , tanto por la información prestada como por el tiempo que han dedicado a la realización de este proyecto.

A la universidad Carlos III de Madrid por permitirme utilizar los ordenadores del área de mecánica para simular las redes neuronales.

## BIBLIOGRAFIA.

- [1] E. Rivas Trujillo; “Detección de averías en cambiadores de tomas en carga de transformadores basado en el patrón de vibraciones”, Leganés 2009.
- [2] Pedro Isasi Viñuela; Inés M. Galván León; “Redes Neuronales Artificiales Un enfoque práctico”.
- [3] José R. Hilera; Víctor J. Martínez, “Redes Neuronales Artificiales, Fundamentos, Modelos y Aplicaciones”.
- [4] Handley, B. et al “On Load Tap-Changer Conditioned Based Maintenance” IEE Proc Generation Transmission Distribution Vol 148 No 4,jul 2001.
- [5] M. Duval “The Duval Triangle for Load Tap Changers, Non-Mineral Oils and Low Temperature Faults in Transformers” IEEE Electrical Insulation Magazine.
- [6] Doble Engineering Company” Condition Assessment Of Load Tap Changer Using Static And Dynamic Contact Resistance” 2004,pp 1-13.
- [7] E. Rivas, D.Urquiza, JC. Burgos “Diagnóstico de Averías en Cambiadores de Tomas en Carga”; ALTAE 2005- IEEE- VII congreso latinoamericano y IV Congreso Iberoamericano en alta tensión y aislamiento eléctrico.
- [8] Pengju Kang and D. Birtwhistle. (2003, Condition Assessment Of Power Transformer On-Load Tap Changers Using Wavelet Analysis And Self-Organizing Map: Field Evaluation. Power Delivery, IEEE Transactions On 18(1), pp. 78-84.
- [9] P. Kang, D. Birtwhistle and K. Khouzam. (1998, Transient Signal Analysis And Classification For Condition Monitoring Of Power Switching Equipment Using Wavelet Transform And Artificial Neural Networks. Knowledge-Based Intelligent Electronic Systems, 1998. Proceedings KES '98. 1998 Second International Conference On 2pp. 73-79 vol.2.
- [10] E. Rivas, J. C. Burgos and J. C. García-Prada. (2009, Condition Assessment Of Power OLTC By Vibration Analysis Using Wavelet Transforms. Power Delivery, IEEE Transactions on 24(2), pp. 687-694.
- [11] T. Bengtsson; Kols, H.; Foata, M. “Monitoring Tap Changer Operations” CIGRE. Paris 1998. Paper 12-209.
- [12] T. Bengtsson,M. Foata, C. Rajotte, et Al, “Acoustic Diagnosis Of Tap Changers,” Cigre, Sweden 1996.
- [13] P. Kang and D. Birtwhistle. (2002, Condition Assessment Of Power Transformer On-Load Tap-Changers Using Wavelet Analysis And Self-Organizing map: Field Evaluation. Power Engineering Review, IEEE 22(8), pp. 69-69.

- [14] M. Foata, C. Landry, and C. Rajotte, "On-Line Acoustic System For The Diagnostic Strategy Of Tap Changers," Cigre, Merida Colloquium, june 2003.
- [15] L. de Almeida, M. Fontana, F. A. Wegelin and L. Ferreira. (2005, A New Approach For Condition Assessment Of On-Load Tap-Changers Using Discrete Wavelet Transform. Instrumentation And Measurement Technology Conference, 2005. IMTC 2005. Proceedings Of The IEEE 1pp. 653-656.
- [16] E. F. Simas, L. A. L. de Almeida and A. C. de Lima. (2005, Vibration monitoring of on-load tap changers using a genetic algorithm. Instrumentation and Measurement Technology Conference, 2005. IMTC 2005. Proceedings of the IEEE 3pp. 2288-2293.
- [17] F. A. Wegelin, R. S. Magalhaes, L. A. L. de Almeida And M. Fontana. (2005, Condition Monitoring Of Power Transformers Using Acoustic Signal Prony's Analysis. Instrumentation and Measurement Technology Conference, 2005. IMTC 2005. Proceedings Of The IEEE 2pp. 1384-1387.
- [18] Kerry Williams, "Condition Monitoring Of OLTC's Using Vibration Analysis"; TechCon Asia-Pacif 2006 Page(s) 61-76.
- [19] E. F. S. Filho and L. A. L. de Almeida. (2008, Self-Organized Classification Of On-Load Tap Changers Acoustic Signatures. Instrumentation And Measurement Technology Conference Proceedings, 2008. IMTC 2008. IEEE pp. 1051-1056.
- [20] Wang, M.; Vandermaar, A.J.; Srivastava, K.D. "Review Of Condition Assessment Of Power Transformers In Service" Electrical Insulation Magazine IEEE Volume 18, Issue 6, Nov.-Dec.2002 Pages:12-25.
- [21] P. Kang "On-Line Condition Assessment Of Power Transformer On-Load Tap-Changers: Transient Vibration Analysis Using Wavelet Transform An Self-Organizing Map" Ph.D. Dissertation, Queensland University of Technology, 2000.
- [22] P. Kang and D. Birtwhistle. (2001, Condition Monitoring Of Power Transformer On-Load Tap-Changers. I. Automatic Condition Diagnostic. Generation, Transmission And Distribution, IEEE proceeding-148(4),pp 301-306).
- [23] Omar José Lara Castro;"Nuevas Metodologías No Invasivas De Diagnosis de Defectos Incipientes En Rodamientos De Bola", Leganés 2007.